

## BAB II

### MATERI PENUNJANG

Dalam bagian ini akan disajikan beberapa teori-teori dasar statistik klasik, khususnya mengenai statistika inferensi dan beberapa teorema yang penting untuk mendukung pembahasan berikutnya. Setelah itu akan digunakan metode bootstrap untuk menaksir parameter. Metode bootstrap yang akan dibahas nanti adalah metode bootstrap dari *Efron*.

#### 2.1 Kekonvergenan dari Variabel Random dalam Statistika

Misalkan  $\{X_n\}$  adalah penulisan dari sebuah barisan dari variabel random  $(X_1, X_2, \dots, X_n)$  dengan distribusi yang sama dan didefinisikan pada ruang sampel  $\Omega$  yang sama. Misalkan  $X$  variabel random yang didefinisikan pada ruang yang sama.

**Defenisi 2.1.1:**  $\{X_n\}$  disebut konvergen secara probalitive ke suatu variabel random  $X$  (ditulis,  $X_n \xrightarrow{p} X$ ),  $\forall \varepsilon > 0$ . Untuk  $n \rightarrow \infty$  berlaku

$$P[|X_n - X| \geq \varepsilon] \rightarrow 0.$$

**Teorema 2.1.1:** Misalkan  $X_n \xrightarrow{p} X$  dan  $Y_n \xrightarrow{p} Y$ , maka

$$X_n + Y_n \xrightarrow{p} X + Y$$

**Bukti:** Teorema ini dibuktikan menurut *defenisi 2.1.1* yaitu sebagai berikut:

$X_n \xrightarrow{p} X$  maka dengan *defenisi 2.1.1*  $P[|X_n - X| \geq \varepsilon] \rightarrow 0$  untuk  $n \rightarrow$

$\infty$   $Y_n \xrightarrow{p} Y$ , maka dengan *defenisi 2.1.1*  $P[|Y_n - Y| \geq \varepsilon] \rightarrow 0$  untuk  $n \rightarrow \infty$ .

$$\begin{aligned}
P[|(X_n + Y_n) - (X + Y)| \geq \epsilon] &= P[|(X_n - X) + (Y_n - Y)| \geq \epsilon] \\
&\leq P[|X_n - X| + |Y_n - Y| \geq \epsilon] \\
&\leq P[|X_n - X| \geq \epsilon/2 + |Y_n - Y| \geq \epsilon/2]
\end{aligned}$$

Dua suku terakhir untuk  $n \rightarrow \infty$  masing-masing akan mencapai nol. Jadi sebagai hasil akhirnya:

$$P[|(X_n + Y_n) - (X + Y)| \geq \epsilon] \rightarrow 0 \text{ jika } n \rightarrow \infty.$$

**Teorema 2.1.2:** Jika  $X_n \xrightarrow{p} X$  dan  $a$  konstan maka  $aX_n \xrightarrow{p} aX$

**Bukti:** Jika  $a = 0$  maka dengan sendirinya teorema terbukti karena  $0 \xrightarrow{p} 0$ .

Anggap  $a \neq 0$ , Untuk setiap  $\epsilon > 0$ ,

$$\begin{aligned}
P[|aX_n - aX| \geq \epsilon] &= P[|a| |X_n - X| \geq \epsilon] \\
&= P[|X_n - X| \geq \epsilon/|a|] \rightarrow 0 \text{ jika } n \rightarrow \infty.
\end{aligned}$$

**Defenisi 2.1.2:**  $X_n$  konvergen ke  $X$  dalam distribusi (ditulis,  $X_n \xrightarrow{d} X$ ).

Untuk ini fungsi distribusi dari  $X_n$  dan  $X$  masing-masing dinyatakan dengan  $F_n(x)$  dan  $F(x)$ . Bila  $F_n(x) \rightarrow F(x)$ ,  $n \rightarrow \infty$  untuk semua titik  $x$  dimana  $F(x)$  kontinu, maka dinyatakan bahwa barisan  $X_n \xrightarrow{d} X$ .

Dalam kasus seperti ini, dikatakan bahwa  $F_n(x) = F_{X_n}(x)$  konvergen lengkap ke  $F(x) = F_X(x)$ , ditulis  $F_n \rightarrow F$ .

## 2.2 Model Regresi Linier

Dalam regresi linier dibedakan dua jenis variabel yaitu  $X$  yang merupakan variabel bebas (prediktor) sedangkan  $y$  merupakan variabel terikat (respon).

Sebuah model regresi linier yang mencakup lebih dari satu variabel bebas disebut *model regresi berganda*. Model umum regresi linier adalah

$$y = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i, \quad (2.2.1)$$

dengan:  $\beta_0, \beta_1, \dots, \beta_k$  parameter-parameter.

Pada umumnya model tersebut dapat ditulis dengan :

$$y = \sum_{j=1}^k \beta_j X_{ij} + \varepsilon_i \text{ dengan } X_{i0} = 1, \text{ untuk } i = 1 \quad (2.2.2)$$

Model linier pada (2.2.1) dapat ditulis sebagai berikut:

$$y_i = X_i \beta + \varepsilon_i \quad \text{untuk } i = 1, 2, \dots, n \quad (2.2.3)$$

$\varepsilon_i$  adalah galat acak yang tak teramati. Atau dalam bentuk matriks model (2.2.3) dapat ditulis sebagai berikut:

$$y = X\beta + \varepsilon \quad (2.2.4)$$

untuk  $k$  buah peubah bebas  $X_1, X_2, \dots, X_k$ , dimana:

$$y = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}_{n \times 1} \quad X = \begin{bmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{bmatrix}_{n \times k} \quad \beta = \begin{bmatrix} \beta_0 \\ \vdots \\ \beta_k \end{bmatrix}_{k \times 1} \quad \text{dan } \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_k \end{bmatrix}_{k \times 1}$$

Agar parameter  $\beta$  mudah dibuat taksirannya maka diasumsikan  $\varepsilon_i$  memenuhi kondisi Gauss-Markov (G – M), yakni:

$$\begin{aligned} (1) \quad & E_F(\varepsilon_i) = 0 \\ (2) \quad & E_F(\varepsilon_i^2) = \sigma^2 \\ (3) \quad & E_F(\varepsilon_i \varepsilon_j) = 0, \quad i \neq j \end{aligned} \quad (2.2.5)$$

untuk semua  $i, j = 1, 2, \dots, n$ . Apabila kondisi (G – M) dipenuhi maka:

$$\mu_i = E(y_i | X_i) = E(X_i \beta + \varepsilon_i | X_i) = E(X_i \beta | X_i) + E(\varepsilon_i | X_i) = X_i \beta \quad (2.2.6)$$

Selanjutnya akan ditaksir parameter regresi  $\beta$  dari observasi data  $((X_1, y_1), \dots, (X_n, y_n))$ . Katakanlah  $\hat{\beta} = \theta$ , suatu taksiran untuk  $\beta_i$  dimana  $\theta = (\theta_0, \theta_1, \dots, \theta_k)$ .

Dari model (2.2.3) didapatkan  $\varepsilon_i = y_i - X_i \beta$ , maka kedua ruas dikuadratkan dan sekaligus dijumlahkan, ini disebut dengan Kuadrat Galat Sisa

(KGS). Jadi,  $KGS(\beta) = \sum_{i=1}^n [y_i - x_i \beta]^2$  atau dalam bentuk matriks sebagai

$$\begin{aligned} \text{berikut: } KGS(\beta) &= (y - X\beta)'(y - X\beta) = y'y - \beta'X'y - y'X\beta + \beta'X\beta \\ &= y'y - \beta'X'y - \beta'X'y + \beta'X\beta \\ &= y'y - 2\beta'X'y + \beta'X\beta \end{aligned}$$

karena  $\beta'X'y$  adalah matrik skalar maka tranpose  $(\beta'X'y)' = \beta'X'y$ . Suatu penaksir

kuadrat terkecil (PKT), misalkan  $\hat{\beta}$ , didapatkan dengan cara meminimumkan

$KGS(\beta)$ . Untuk meminimumkannya maka  $KGS(\beta)$  diturunkan terhadap masing-

masing  $\beta_i$  dan turunan ini sama dengan nol, diperoleh

$$\partial JKG(\beta)/\partial \beta = -2 X'y + 2X'X\beta = 0.$$

Dengan meletakkan  $\theta$  pada  $\beta$  dan PKT  $(\hat{\beta}) = \theta$  diberikan oleh persamaan  $X'X\theta$

$= X'y$  dan dari penyelesaian persamaan normal didapat

$$\theta = (X'X)^{-1} X'y \quad (2.2.7)$$

Dengan menggantikan  $\beta$  dengan  $\theta$  dan  $\varepsilon$  dengan  $e$  maka model prediksi (2.2.4)

menjadi:  $y = X\theta + e$ , dimana  $e$  adalah suatu taksiran untuk  $\varepsilon$ .

Sekarang diperkirakan model regresi tersebut adalah  $\hat{\mathbf{y}} = \mathbf{X}\theta$  dan didefinisikan vektor sisa  $\mathbf{e} = \mathbf{y}_i - \hat{\mathbf{y}}$ , yakni suatu penyimpangan prediksi dari nilai sebenarnya, dimana

$$\mathbf{e} = (e_1, e_2, \dots, e_n), \text{ dan } \hat{\mathbf{y}} = \begin{bmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \vdots \\ \hat{y}_n \end{bmatrix} = \mathbf{X}\theta = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$$

### 2.3 Rataan dan Variansi untuk Penaksir Parameter $\theta$

Dibawah kondisi G-M maka diperoleh:

$$E(\theta) = E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}] = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'E[\mathbf{y}] = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\beta = \beta \quad (2.3.1)$$

Hal ini menunjukkan bahwa  $\theta$  suatu penaksir yang tak bias untuk  $\beta$ . Kemudian

$$\text{Cov}(\mathbf{y}) = E[(\mathbf{y} - \mathbf{X}\beta)(\mathbf{y} - \mathbf{X}\beta)'] = E(\epsilon\epsilon') = \sigma^2\mathbf{I} \quad (2.3.2)$$

Misalkan  $\mathbf{A} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$  maka (2.2.6) menjadi

$$\theta = \mathbf{A}\mathbf{y} \quad (2.3.3)$$

Selanjutnya, menurut kondisi G-M,

$$\begin{aligned} \text{Cov}(\theta) &= \text{Cov}(\mathbf{A}\mathbf{y}) = \mathbf{A}\text{Cov}(\mathbf{y})\mathbf{A}' = \mathbf{A}\sigma^2\mathbf{I}\mathbf{A}' = \mathbf{A}\mathbf{A}'\sigma^2 \\ &= \sigma^2(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X} = \sigma^2(\mathbf{X}'\mathbf{X})^{-1} \end{aligned} \quad (2.3.4)$$

Supaya  $\text{Cov}(\theta)$  dapat ditaksir, maka akan ditentukan lebih dahulu

taksiran untuk  $\sigma^2$  (yang mana biasanya tidak diketahui) yaitu,

$$S^2 = \sum_{i=1}^n e_i^2 (n - k - 1)^{-1} = \text{JKS} / n - k - 1 \quad (2.3.5)$$

Sekarang dapat ditentukan taksiran untuk Cov ( $\theta$ ), yaitu:

$$\text{Cov}(\theta) = S^2 (\mathbf{X}'\mathbf{X})^{-1} = S^2 G^{ij}$$

Misalkan  $G^{ij}$  adalah elemen diagonal ke- $j$  dari matriks  $(\mathbf{X}'\mathbf{X})^{-1}$  yang merupakan  $\text{var}(\theta_j)$ , variansi penaksir  $\theta_j$ . Dan standar error (s.e.) dari  $\theta_j$  adalah  $\text{s.e.}(\theta_j) = S\sqrt{G^{jj}}$ .

#### 2.4 Selang Kepercayaan untuk $\beta$ pada Regresi Linier

Dalam hal ini diasumsikan kondisi G-M dipenuhi dan juga diasumsikan bahwa  $\varepsilon \sim N(0, \sigma^2 \mathbf{I}_n)$ , yakni normal  $n$ -variate. Karena  $\mathbf{X}$  bukan acak (matriks konstan), maka

$$\mathbf{y} \sim N(\mathbf{X}\beta, \sigma^2 \mathbf{I}) \quad (2.4.1)$$

Dari (2.3.3) diperoleh  $\theta = \mathbf{A}\mathbf{y}$ , dimana  $\mathbf{A}$  suatu matriks konstan maka didapatkan:

$$\theta \sim N(\mathbf{A}\beta, \mathbf{A}\sigma^2 \mathbf{A}') \text{ atau}$$

$$\theta \sim N(\beta, \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}) \quad (2.4.2)$$

Ini berarti bahwa

$$\theta \xrightarrow{d} \beta, \quad (2.4.3)$$

untuk parameter ke-j

$$\theta_j \sim N(\beta_j, \sigma^2 G^{jj}). \quad (2.4.4)$$

Jika dibakukan diperoleh:

$$\frac{\theta_j - \beta_j}{\sigma \sqrt{G^{jj}}} \sim N(0,1). \quad (2.4.5)$$

Telah diketahui  $S \sqrt{G^{jj}} = \text{s.e.}(\theta_j)$  maka, menurut teori peluang, dari persamaan (2.3.5) didapatkan:

$$(n-k-1) S^2 / \sigma^2 \sim \chi_{(n-k-1)}^2 \quad (2.4.6)$$

Berdasarkan (2.4.5) dan (2.4.6) diperoleh:

$$\begin{aligned} \frac{\left( \frac{\theta_j - \beta_j}{\sigma \sqrt{G^{jj}}} \right)}{\sqrt{\frac{(n-k-1)S^2 / \sigma^2}{(n-k-1)}}} &= (\theta_j - \beta_j) / (S \sqrt{G^{jj}}) \\ &= [(\theta_j - \beta_j) / \text{s.e.}(\theta_j)] \sim t_{(n-k-1)} \end{aligned} \quad (2.4.7)$$

Selanjutnya berdasarkan (2.4.7) dapat dibuat selang kepercayaan  $(1-2\alpha)$

100% untuk parameter  $\beta_j$  sebagai berikut:

$$P(L < \beta_j < U) = (1-2\alpha), \text{ asalkan } P(L \geq \beta_j) = \alpha, \text{ dan } P(U \leq \beta_j) = \alpha.$$

Disini L adalah batas bawah selang dan U batas atas selang.

Jadi, selang kepercayaan  $(1-2\alpha)$  100% untuk  $\beta_j$  adalah:

$$\theta_j + \text{s.e.}(\theta_j) t_{(n-k-1), \alpha}, \theta_j - \text{s.e.}(\theta_j) t_{(n-k-1), \alpha} \quad (2.4.8)$$

## 2.5 Model Distribusi Empiris dan Prinsip Penggantian (*Plug-in*)

Pandang  $X_1, X_2, \dots, X_n$  sampel random berukuran  $n$  dari populasi yang berdistribusi  $F$  yang tidak diketahui dan misalkan  $X_i \stackrel{iid}{\sim} F$ . Parameter sebagai fungsi dari  $F$  dinotasikan

$$\theta = t(F),$$

yang merupakan nilai sebenarnya dari parameter yang akan ditaksir. Parameter  $\theta$  dapat dipandang sebagai nilai fungsi sebenarnya dari  $F$ . Distribusi sebenarnya  $F$  tidak diketahui, akan tetapi berdasarkan sampel  $X_1, X_2, \dots, X_n$  maka  $F$  dapat ditaksir dengan memakai *fungsi distribusi empiris*  $\hat{F}_n$ .

Fungsi distribusi empiris  $\hat{F}_n$  dari  $X_1, X_2, \dots, X_n$  didefinisikan sebagai berikut:

$$\hat{F}_n(x) = \frac{1}{n} \#\{x_i \leq x, 1 \leq i \leq n\}, \text{ untuk } -\infty < x < \infty. \quad (2.5.1)$$

Dengan kata lain  $\hat{F}_n$  adalah suatu fungsi distribusi empiris dengan memberikan bobot peluang  $1/n$  pada setiap observasi  $x_i$ ,  $i = 1, 2, \dots, n$ .  $\hat{F}_n$  adalah penaksir yang baik dari  $F$  karena tidak bias, artinya  $E(\hat{F}_n(x)) = F$ . Dan menurut teorema 2.1.1 berarti

$$\hat{F}_n \rightarrow F \quad (2.5.2)$$

Prinsip penggantian (*Plug-in Principle*) adalah metode sederhana penaksiran parameter-parameter dari sampel. Sebuah penaksir pengganti dari

parameter  $\theta = t(F)$  akan ditaksir kembali dengan prinsip penggantian yang didefinisikan sebagai:

$$\hat{\theta} = t(\hat{F}).$$

Dengan kata lain, penaksir fungsi  $\theta = t(F)$  dari distribusi peluang  $F$  sama saja dengan menaksir parameter dari fungsi distribusi empiris  $\hat{F}_n$ , atau  $\hat{\theta} = t(\hat{F})$ .

Untuk selanjutnya istilah penaksir pengganti dapat disebut sebagai penaksir saja, dengan lambang “ $\hat{\cdot}$ ”.

## 2.6 Metode bootstrap

Metode bootstrap diperkenalkan dalam statistika oleh *Bradley Efron* pada tahun 1977 sebagai suatu metode untuk menaksir variabilitas dari suatu statistik, seperti galat baku atau dengan membentuk selang kepercayaan. Dapat juga digunakan untuk menaksir distribusi suatu statistik (disebut distribusi bootstrap dari statistik tersebut). Distribusi ini diperoleh dengan menggantikan distribusi populasi yang tidak diketahui dengan distribusi empiris berdasarkan data sampel, kemudian melakukan resampel kembali dari distribusi empiris untuk dipergunakan dalam mencari penaksir bootstrap.

Misalkan  $X_1, X_2, \dots, X_n$  sampel random berukuran  $n$  dari suatu populasi dengan fungsi distribusi  $F$  tidak diketahui. Misalkan juga  $\theta = t(F)$  parameter populasi yang menjadi perhatian dan yang akan ditaksir. Penaksir dari  $\theta$ ,  $\hat{\theta}$ , adalah suatu fungsi dari  $X_1, X_2, \dots, X_n$ , misalkan kuantitas statistiknya

$$K_n = u(x_1, x_2, \dots, x_n; F) \quad (2.6.1)$$

yang merupakan fungsi dari  $(x_1, x_2, \dots, x_n)$  dan  $F$ . Yang ingin dicari adalah distribusi dari  $K_n$ , dan misalkan fungsi distribusinya adalah

$$G_n(x) = P(K_n \leq x) \quad (2.6.2)$$

untuk  $-\infty \leq x \leq \infty$ . Jelas  $G_n$  tidak diketahui karena  $F$  tidak diketahui.

Berdasarkan  $(x_1, x_2, \dots, x_n)$ , yang mempunyai distribusi empiris  $\hat{F}_n$  yang memberi peluang  $1/n$  pada setiap observasi dari  $x_i, i = 1, 2, \dots, n$ :

$$\hat{F}_n(x) = \frac{1}{n} \{ \text{banyaknya } x_i \leq x, 1 \leq i \leq n \} \quad (2.6.3)$$

untuk  $-\infty \leq x \leq \infty$ .  $\hat{F}_n$  adalah penaksir yang baik dari  $F$  karena tidak bias.

**Sampel bootstrap** didefinisikan sebagai sampel random berukuran  $n$  yang diambil dari  $\hat{F}_n$  dengan pengembalian, ditulis  $x_1^*, x_2^*, \dots, x_n^*$ . Jadi ada  $n^n$  kombinasi yang mungkin untuk sampel bootstrap, bisa saja didapatkan  $x_i^* = x_j^*$ , untuk  $i \neq j$ . Pada sampel bootstrap,  $x_i$  bisa muncul nol kali, bisa satu kali dan maksimal  $n$  kali.

Dengan kata lain ada  $n$  cara untuk memperoleh masing-masing  $x_1^*, x_2^*, \dots, x_n^*$ . Jika

$x_i, i = 1, 2, \dots, n$ ,  $n$  buah nilai berbeda, maka ada  $\binom{2n-1}{n}$  sampel bootstrap yang

berbeda.

Setiap sampel bootstrap berkorespondensi dengan satu *replikasi bootstrap*

untuk  $K_n$  yang didefinisikan sebagai

$$K_n^* = u(x_1^*, \dots, x_n^*; \hat{F}_n) \quad (2.6.4)$$

Sedangkan *penaksir bootstrap* untuk fungsi distribusi dari  $K_n$  didefinisikan sebagai

$$G_n^* = P^*(K_n^* \leq x). \quad (2.6.5)$$

dimana  $P^*$  adalah peluang yang berkorespondensi dengan  $\hat{F}_n$ . Penaksir bootstrap

$G_n^*$  tidak lain adalah fungsi distribusi *bersyarat* dari  $K_n$  dengan syarat  $\hat{F}_n$

diberikan, yaitu dengan observasi dari  $(x_1, x_2, \dots, x_n)$  yang diberikan. Untuk

menegaskan kebersyaratan tersebut (2.6.5) dapat dituliskan sebagai

$$G_n^* = P^*(K_n^* \leq x | x_1, \dots, x_n). \quad (2.6.6)$$

Namun untuk memudahkan penulisan, dipakai (2.6.5).

Dalam hal ini penaksir bootstrap  $(x_1^*, x_2^*, \dots, x_n^*)$  pengganti dari  $x_1, x_2, \dots, x_n$  dan  $\hat{F}_n$  penaksir pengganti dari  $F$ . Dengan kata lain dalam metode bootstrap  $\hat{F}_n$  dipandang sebagai populasi.

Tanda “\*” menunjukkan bahwa  $x^*$  bukan data sesungguhnya  $x$  melainkan bentuk random dari  $x$ , atau hasil *resampling* dari data  $x$  secara random dengan pengembalian.

Pembahasan berikut adalah penjabaran tentang langkah-langkah dasar untuk metode bootstrap menurut *Efron*.

1. Menentukan distribusi empiris dari  $F$ , yaitu  $\hat{F}_n(x)$  dengan memberi peluang  $1/n$  untuk masing-masing titik  $x_1, x_2, \dots, x_n$ .
2. Menentukan sampel bootstrap  $(x_1^*, x_2^*, \dots, x_n^*)$ .

Menurut  $\hat{F}_n(x)$  yang telah ditentukan, diambil sampel bootstrap ukuran  $n$  secara random dari  $x_1, x_2, \dots, x_n$  dengan pengembalian, sebut nilai sampelnya  $(x_1^*, x_2^*, \dots, x_n^*)$ .

3. Menentukan statistik bootstrap  $\hat{\theta}^*$ .

Dari  $x_1^*, x_2^*, \dots, x_n^*$  yang diperoleh pada langkah ke-2, selanjutnya hitung statistik bootstrap untuk menghasilkan  $\hat{\theta}^*$ .

4. Menentukan  $K_n^* = u(x_1^*, \dots, x_n^*; \hat{F}_n)$ .

Yaitu dengan menghitung  $K_n^* = \sqrt{n}(\hat{\theta}^* - \hat{\theta})$ .

5. Menentukan distribusi  $K_n^*$ .

Kita pelajari sifat-sifat dari  $K_n^*$ , misalnya untuk menentukan rata-rata dari  $K_n^*$ .

6. Ulangi langkah 2,3,4 dan 5 sebanyak B kali, untuk B yang cukup besar.

7. Berikan sebaran peluang dari  $\hat{\theta}^*$  dengan menempatkan peluang bagi masing-masing  $\hat{\theta}_1^*, \hat{\theta}_2^*, \dots, \hat{\theta}_B^*$ . Sebaran ini adalah estimasi bootstrap untuk sebaran sampling  $\hat{\theta}^*; F^*(\hat{\theta}^*)$ .

Langkah-langkah inilah yang disebut sebagai dasar untuk metode bootstrap. Secara teoritis, kemungkinan  $x_1^*, x_2^*, \dots, x_n^*$  yang muncul adalah terhingga, yaitu sebanyak  $n^n$  kemungkinan. Hal ini dapat dilihat pada contoh dibawah ini.

Misalkan  $X = (X_1, X_2, X_3)$  sampel random berukuran  $n = 3$  dari suatu  $F$  dan  $x = (x_1, x_2, x_3) = (3, 6, 9)$  adalah hasil pengamatan. Selanjutnya akan ditaksir distribusi sampling dari  $K_n = u(x_1, x_2, \dots, x_n; F) = \sqrt{n}(\hat{\theta} - \theta)$ , maka yang harus dilakukan adalah :

1.  $\hat{F}_n(x)$  memberi peluang  $1/3$  untuk setiap  $(3, 6, 9)$ .
2. Menurut ketentuan dari  $\hat{F}_n(x)$  diambil sampel bootstrap berukuran  $n = 3$ , maka  $x^*$  yang mungkin adalah:  
 $\{(3, 3, 3), (3, 3, 6), (3, 3, 9), (3, 6, 3), (3, 9, 3), (6, 3, 3), (9, 3, 3), (3, 6, 6), (3, 9, 9), (6, 6, 6), (6, 6, 3), (6, 6, 9), (6, 3, 6), (6, 9, 6), (3, 6, 6), (9, 6, 6), (6, 3, 3), (6, 9, 9), (9, 9, 9), (9, 9, 3), (9, 9, 6), (9, 3, 9), (9, 6, 9), (3, 9, 9), (6, 9, 9), (9, 3, 3), (9, 6, 6)\}$
3. Tentukan  $\theta(\hat{F})$  dari  $\bar{x} = \sum_{i=1}^3 x_i / 3$ , yaitu:  $\hat{\theta} = (3+6+9) / 3 = 6$
4. Dari  $x^*$ , ditentukan  $\hat{\theta}^*$ .

Untuk setiap pengambilan sampel bootstrap akan dihitung  $\hat{\theta}_n^* = \sum_{i=1}^3 x_i / n$ ,

untuk  $n = 1, 2, \dots, 27$ , yaitu:

$$\hat{\theta}_n^* = (3+3+3) / 3$$

$$\hat{\theta}_n^* = (3+3+6) / 3$$

$$\hat{\theta}_n^* = (3+3+9) / 3$$

$$\hat{\theta}_{27}^* = (9+6+6) / 3$$

5. Menentukan  $K_n^*$ , yaitu  $K_n^* = u(x_1^*, \dots, x_n^*; \hat{F}_n) = \sqrt{n}(\hat{\theta}_n^* - \hat{\theta})$ , dimana  $\hat{\theta}_n^*$

adalah rata-rata dari salah satu ( $3^3$ ) kemungkinan  $x^*$  yang mungkin.

$$K_1^* = \sqrt{3} \times (3-6) = -5.1961524$$

$$K_2^* = \sqrt{3} \times (4-6) = -3.4641016$$

$$K_3^* = \sqrt{3} \times (5-6) = -1.7320508$$

$$K_{27}^* = \sqrt{3} \times (7-6) = 1.7320508$$

6. Hitung distribusi bootstrap dari  $K_n^* = u(x_1^*, \dots, x_n^*; \hat{F}_n)$ .

Untuk lebih jelasnya akan diterapkan hasil perhitungan dalam tabel dibawah ini:

Tabel 2.6.1 Sebaran frekuensi rata-rata resampling untuk  
( $X_1, X_2, X_3$ ) = ( 3, 6, 9 )

| i | $\hat{\theta}_{3i}$ | $\sqrt{n}(\hat{\theta}_{3i} - \hat{\theta})$<br>( $K_{ni}$ ) | Frekwensi<br>( $f_i$ ) | Frekwensi<br>Relatif<br>( $P_i$ ) | Frekwensi<br>Relatif<br>Kumulatif |
|---|---------------------|--|------------------------|-----------------------------------|-----------------------------------|
| 1 | 3                   | -5.1961524   | 1                      | 1/27                              | 1/27                              |
| 2 | 4                   | -3.4641016   | 4                      | 4/27                              | 5/27                              |
| 3 | 5                   | -1.7320508   | 8                      | 8/27                              | 12/27                             |
| 4 | 6                   | 0  | 1                      | 1/27                              | 14/27                             |
| 5 | 7                   | 1.7320508  | 8                      | 8/27                              | 22/27                             |
| 6 | 8                   | 3.4641016  | 4                      | 4/27                              | 26/27                             |
| 7 | 9                   | 5.1961524  | 1                      | 1/27                              | 1                                 |
|   |                     | Jumlah   | 27 = $3^3$             | 1                                 |                                   |

Resampling dilakukan dengan pengembalian untuk semua kemungkinan sampel.

Rataan setiap sampel bootstrap ( $\hat{\theta}_{3i}^*$ ) menyebar seperti pada tabel 2.6.1. Penaksir

bootstrap  $G_{3i}^*(x) = P^* \left( \sqrt{3} \left( \hat{\theta}_{3i}^* - \hat{\theta} \right) < x \right)$  untuk setiap nilai  $x$  bagi  $\sqrt{3} \left( \hat{\theta} - \theta \right)$

adalah  $G_3^*(x) = \sum_{i=1}^9 P_i$ .

Semakin besar  $n$  semakin baik ( dalam arti, ini dikaitkan apabila grafik histogram dari hasil  $K_n$  sudah cukup menyerupai grafik distribusi normal ). Meskipun secara prinsip dapat dihitung, tapi bisa dikatakan mustahil dalam prakteknya karena membutuhkan waktu yang lama sekali, apalagi jika bentuk  $K_n$  nya rumit. Ini menjadi tidak efektif lagi, sehingga digunakan pendekatan *simulasi Monte-Carlo*, dimana semua kemungkinan sampel bootstrap dibuat menjadi sejumlah  $B$  yang cukup besar (tetapi cukup kecil jika dibandingkan dengan jumlah sampel bootstrap ideal, akan tetapi cukup menunjukkan grafik histogram daripada  $K_n^*$  untuk mendekati grafik distribusi normal).  $B$  dinamakan *umuran bootstrap*. Dengan bantuan paket komputer dalam bahasa *pascal* hal tersebut dapat dilakukan dengan mudah.

Simulasi Monte-carlo dapat digunakan, karena dengan teorema limit pusat akan menjamin kekonsistenan dari  $G_n^{*B}$  ke  $G_n^*$ .

Distribusi normal merupakan jenis distribusi dengan variabel random kontinyu. Jika  $X$  variabel random kontinyu mempunyai fungsi dentitas

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left[\frac{x-\mu}{\sigma}\right]^2} \text{ untuk } -\infty < x < \infty, \text{ maka dikatakan variabel } X$$

berdistribusi normal.

**Teorema limit pusat ( central limit pusat )**

Jika  $\{ X_n \}$  adalah barisan dari variabel random yang independen dan didistribusikan secara identik dengan kesamaan nilai harapan dan varian yang terbatas, maka variabel random  $Y_n = \frac{\sum X_i - n\mu}{\sigma\sqrt{n}} = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}$

mempunyai limit untuk  $n \rightarrow \infty$  sama dengan distribusi  $N(0,1)$ .

**Bukti:**

Dalam hal ini dianggap, bahwa barisan  $\{ X_n \}$  mempunyai fungsi pembangkit momen  $m_X(t) = E[e^{tx}]$   $-h < t < h$ .  $\{ X_n \}$  barisan dari sampel random  $X_1, X_2, \dots, X_n$  (adalah independen).

Karena  $X_i$  merupakan barisan yang independen maka untuk fungsi  $Y_n$  juga merupakan barisan yang independen ( $i = 1, 2, \dots, n$ ).

Sehingga berdasarkan defenisi fungsi pembangkit momen dari suatu variabel random maka setiap fungsi dari variabel random mempunyai fungsi pembangkit yang sama, berlaku

$$m_{Y_n}(t) = E[e^{tY_n}]$$

$$= E \left[ e^{t \left( \frac{\sum X_i - n\mu}{\sigma\sqrt{n}} \right)} \right] \quad ; \text{karena } X_1, X_2, \dots, X_n \text{ independen}$$

$$= E \left[ e^{t \left( \frac{X_1 - \mu}{\sigma \sqrt{n}} \right)} \right] \cdot E \left[ e^{t \left( \frac{X_2 - \mu}{\sigma \sqrt{n}} \right)} \right] \cdot \dots \cdot E \left[ e^{t \left( \frac{X_n - \mu}{\sigma \sqrt{n}} \right)} \right]$$

$$= E \left[ e^{t \left( \frac{X - \mu}{\sigma \sqrt{n}} \right)} \right]^n$$

$$= E \left[ m_z \left( \frac{t}{\sigma \sqrt{n}} \right) \right]^n \quad \text{dimana } z = X - \mu \text{ dan } -h < \frac{t}{\sigma \sqrt{n}} < h.$$

Dengan menggunakan deret Taylor :

$$m_z(s) = m_z(0) + m_z'(0)s + \frac{m_z''(s_0)s^2}{2} + \dots ; 0 < s_0 < s \text{ dimana } s = \frac{t}{\sigma \sqrt{n}}$$

dari sifat fungsi pembangkit momen dimana variabel random  $z = X - \mu$  , maka

$m_z(0) = 1$ ,  $m_z'(0) = E[X - \mu] = 0$  dan  $m_z''(0) = \sigma^2$ , maka deret Taylor dapat

dituliskan:

$$m_z(s) = 1 + \frac{m_z''(s_0)}{2} s^2 + \dots$$

$$m_z \left( \frac{t}{\sigma \sqrt{n}} \right) = 1 + \frac{m_z''(s_0)t^2}{2n\sigma^2} + \dots$$

$$= 1 + \frac{t^2}{2n} + \frac{(m_z''(s_0) - \sigma^2)t^2}{2n\sigma^2} + \dots$$

$$m_{Y_n}(t) = \left[ m_z \left( \frac{t}{\sigma \sqrt{n}} \right) \right]^n$$

$$= \left[ 1 + \frac{t^2}{2n} + \frac{((m_z^2(s_0) - \sigma^2)t^2)}{2n\sigma^2} + \dots \right]^n$$

maka limit  $\lim_{n \rightarrow \infty} m_z^2\left(\frac{s_0}{\sigma\sqrt{n}}\right) = \sigma^2$ , sehingga harga  $m_{Y_n}(t) \rightarrow e^{\frac{t^2}{2}}$  jika  $n \rightarrow \infty$ .

Kesimpulannya  $m(t) = e^{\frac{t^2}{2}}$  atau  $F_{Y_n}(x) \rightarrow \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt$ , dimana  $n \rightarrow \infty$ ,

adalah fungsi pembangkit momen dari  $N(0,1)$  terbukti.

## 2.7 Selang Kepercayaan Bootstrap Parameter $\theta$

Pada bagian ini akan dibuat selang kepercayaan untuk parameter  $\theta = t(F)$

Misalkan  $\hat{\theta} = \hat{\theta}(x_1, \dots, x_n; F)$  adalah suatu statistik penaksir dari parameter  $\theta$ ,

berdasarkan data  $(x_1, x_2, \dots, x_n)$ . Didefinisikan suatu statistik:

$$K_n = \sqrt{n} \left( \hat{\theta} - \theta \right) \quad (2.7.1)$$

Pendefinisian statistik ini adalah idenya dari teorema limit pusat. Mengatakan bahwa jumlah dari peubah acak dikurangi ekspektasinya mempunyai distribusi normal simetris disekitar nol, untuk  $n$  yang cukup besar. Disini diasumsikan statistik tersebut mempunyai distribusi asimptotis normal disekitar nol. Dan

diasumsikan pula  $E(\hat{\theta}) = \theta$ , Jadi merupakan suatu penaksir yang tak bias. Dalam

hal ini  $\hat{\theta}$  adalah suatu *penaksir kuadrat terkecil (PKT)* untuk parameter regresi  $\beta$ ,

dimana  $\hat{\theta}$  tersebut berdistribusi normal dengan rata-rata  $E(\hat{\theta}) = \theta$ . Jadi jumlah hasil dari  $n^{1/2}(\hat{\theta} - \theta)$  akan menghasilkan suatu distribusi normal simetris disekitar nol.

Dengan menggunakan prinsip penggantian dalam metode bootstrap diperoleh

$$K_n^* = \sqrt{n}(\hat{\theta}^* - \hat{\theta}) \quad (2.7.2)$$

yakni dengan mengganti  $K_n$  dengan  $K_n^*$ ,  $\theta^*$  dengan  $\hat{\theta}$  dan  $\hat{\theta}$  merupakan penaksir dari  $\theta$ . Selanjutnya menentukan fungsi distribusi dari  $K_n$  yaitu:

$$G_n(x) = P(K_n(x_1, \dots, x_n; F) \leq x) = P_F\left(\sqrt{n}(\hat{\theta} - \theta) \leq x\right) \quad (2.7.3)$$

dan fungsi distribusi dari  $K_n^*$  adalah

$$G_n^*(x) = P^*\left(K_n^*(x_1^*, \dots, x_n^*; \hat{F}_n) \leq x\right) = P_{\hat{F}_n}^*\left(\sqrt{n}(\hat{\theta}^* - \hat{\theta}) \leq x\right) \quad (2.7.4)$$

Oleh karena  $x_1^*, \dots, x_n^*$  adalah sampel bootstrap yang diambil dari  $x_1, x_2, \dots, x_n$  berdasarkan  $\hat{F}_n$  (distribusi empiris dari  $x_1, x_2, \dots, x_n$ ), maka dengan sendirinya  $G_n^*$  dapat diketahui karena didefinisikan berdasarkan  $\hat{F}_n$ . Jadi  $G_n^*$  merupakan *penaksir bootstrap* dari  $G_n$ .

$G_n^*$  dapat dipandang sebagai penaksir pengganti (*plug-in estimate*) dari  $G_n$  dengan meletakkan  $\hat{F}_n$  ke- $i$  dan  $x_i^*$  ke  $x_i$ . Perhitungan  $G_n^*$  secara eksak berdasarkan semua kemungkinan sampel bootstrap inilah yang disebut "ideal bootstrap". Dengan menggunakan simulasi Monte-Carlo didapat penaksiran  $G_n^*$  yang cukup baik, artinya cukup dekat ke  $G_n$ .

Telah ditulis bahwa  $\hat{F}_n \rightarrow F$ . Selanjutnya karena  $G_n^*$  didefinisikan berdasarkan  $\hat{F}_n$  dan  $G_n$  didefinisikan berdasarkan  $F$ . Maka bisa dikatakan bahwa  $G_n \approx G_n^*$ , untuk pengulangan  $n$  yang cukup besar, dalam arti jika  $a_n = b_n$  maka  $a_n$  dan  $b_n$  dapat diganti. Berdasarkan ini, akan dibangun selang kepercayaan untuk parameter  $\theta$ . Ide dasarnya adalah menempatkan kuantil (yang tak diketahui) dari  $G_n$  dengan menggunakan kuantil (diketahui) dari  $G_n^*$ . Kuantil  $(\alpha)$  dan kuantil  $(1-\alpha)$  dari  $G_n$  didefinisikan sebagai berikut:

$$c_{n\alpha} = G_n^{-1}(\alpha), \quad c_{n1-\alpha} = G_n^{-1}(1-\alpha) \quad (2.7.5)$$

dengan cara yang sama diperoleh kuantil  $(\alpha)$  dan kuantil  $(1-\alpha)$  dari  $G_n^*$ ,

$$c_{n\alpha}^* = G_n^{*-1}(\alpha), \quad c_{n1-\alpha}^* = G_n^{*-1}(1-\alpha). \quad (2.7.6)$$

Karena  $G_n^* \approx G_n$ , untuk  $n$  yang cukup besar maka didapatkan  $c_{n\alpha} \approx c_{n\alpha}^*$  dan  $c_{n1-\alpha} \approx c_{n1-\alpha}^*$ . Selang kepercayaan  $(1-2\alpha)100\%$  untuk  $\theta$  dibentuk sebagai berikut:

$$P\left(c_{n\alpha}^* \leq \sqrt{n}(\hat{\theta} - \theta) \leq c_{n1-\alpha}^*\right).$$

Dalam hal ini,  $P\left(c_{n\alpha}^* \leq \sqrt{n}(\hat{\theta} - \theta) \leq c_{n1-\alpha}^*\right) \approx P\left(c_{n\alpha} \leq \sqrt{n}(\hat{\theta} - \theta) \leq c_{n1-\alpha}\right)$ .

Selang kepercayaan  $(1-2\alpha)100\%$  diperoleh sebagai berikut:

$$\begin{aligned} P\left(c_{n\alpha} \leq \sqrt{n}(\hat{\theta} - \theta) \leq c_{n1-\alpha}\right) &= P\left(\sqrt{n}(\hat{\theta} - \theta) \leq c_{n1-\alpha}\right) - P\left(\sqrt{n}(\hat{\theta} - \theta) \leq c_{n\alpha}\right) \\ &= G_n(c_{n1-\alpha}) - G_n(c_{n\alpha}) \\ &= 1 - (\alpha) - (\alpha) \\ &= 1 - 2\alpha \end{aligned}$$

Sehingga diperoleh

$$c_{n\alpha}^* \leq \sqrt{n}(\hat{\theta} - \theta) \leq c_{n1-\alpha}^* \quad (2.7.7)$$

yang ekuivalen dengan

$$\hat{\theta} - \frac{1}{\sqrt{n}} c_{n1-\alpha}^* \leq \theta \leq \hat{\theta} - \frac{1}{\sqrt{n}} c_{n\alpha}^* \quad (2.7.8)$$

Sehingga dapat diperoleh selang

$$\hat{\theta} - \frac{1}{\sqrt{n}} c_{n1-\alpha}^*, \hat{\theta} - \frac{1}{\sqrt{n}} c_{n\alpha}^* \quad (2.7.9)$$

sebagai selang kepercayaan bootstrap untuk parameter  $\theta$ , dengan taraf kepercayaan mendekati  $(1-2\alpha)$ .

Selanjutnya pendefinisian kuantil  $(\alpha)$  dan kuantil  $(1-\alpha)$  dari distribusi (bersyarat)  $\hat{\theta}^*$  dinyatakan  $\hat{\theta}^{*(\alpha)}$  dan  $\hat{\theta}^{*(1-\alpha)}$ . Jadi, cukup dapat dimengerti jika ditulis  $\sqrt{n}(\hat{\theta}^* - \hat{\theta}) = c_{np}^*$ , untuk suatu nilai  $p \in (0,1)$ . Nilai  $p$  akan diambil sebesar  $(\alpha)$  dan  $(1-\alpha)$ . Dimana bahwa  $\hat{\theta}^*$  bertindak sebagai 'konstanta' dalam lingkungan bootstrap. Dengan demikian diperoleh selang kepercayaan bootstrap sebagai berikut:

$$\hat{\theta} - \sqrt{n}(\hat{\theta}^{*(1-\alpha)} - \hat{\theta}), \hat{\theta} - \sqrt{n}(\hat{\theta}^{*(\alpha)} - \hat{\theta})$$

atau

$$\left( 2\hat{\theta} - \hat{\theta}^{*(1-\alpha)}, 2\hat{\theta} - \hat{\theta}^{*(\alpha)} \right) \quad (2.7.10)$$

dengan  $\hat{\theta}_p^*$  adalah kuantil ke-100p dari distribusi empiris (bersyarat, berdasarkan

$\hat{F}_n$ ) dari  $\hat{\theta}^*$ . Dari (2.7.10) didapatkan

$$\left( \hat{\theta}^{*(\alpha)}, \hat{\theta}^{*(1-\alpha)} \right) \quad (2.7.11)$$

Sekali lagi bahwa  $\hat{\theta}^{*(\alpha)}$  dan  $\hat{\theta}^{*(1-\alpha)}$  menyatakan kuantil  $(\alpha)$  dan kuantil  $(1 - \alpha)$  dari distribusi (bersyarat)  $\hat{\theta}^*$ . Tentu saja  $\hat{\theta}^{*(\alpha)}$  dan  $\hat{\theta}^{*(1-\alpha)}$  dihitung melalui aproksimasi simulasi Monte Carlo. Sehingga diurutkan  $\hat{\theta}_j^*$ ;  $j = 1, \dots, B$ . Harga  $B$  merupakan replikasi semu bootstrap dari  $\hat{\theta}^*$ . Setelah itu diambil nilai statistik terurut yang ke  $(\alpha) \cdot B$  dan ke  $(1-\alpha) \cdot B$  sebagai aproksimasi Monte Carlo dari  $\hat{\theta}^{*(\alpha)}$  dan  $\hat{\theta}^{*(1-\alpha)}$ . Selang kepercayaan Bootstrap seperti pada hasil 2.4.14 oleh Efron disebut *metoda persentil bootstrap*.